

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

Estimativa da qualidade de água em reservatório urbano: abordagem via sensoriamento remoto com VANT, imageamento multiespectral e algoritmo de aprendizagem de máquina

Caio C. S. Mello¹ ; Daniel H. C. Salim²; Bernardo T. A. Souza³; Gabriel Pereira⁴; Camila C. Amorim⁵

Abstract: Urban reservoir degradation necessitates cost-effective, high-resolution monitoring tools. This study investigates the integration of an unmanned aerial vehicle (UAV) equipped with a MicaSense RedEdge Dual-P multispectral sensor and Random Forest machine-learning for estimating four water quality parameters—chlorophyll-a, phycocyanin, turbidity, and Secchi depth—in the eutrophic Ibitité Reservoir (Minas Gerais, Brazil). Six monthly campaigns at 19 sampling points synchronized in situ measurements and aerial imagery. Following radiometric correction, reflectance extraction, and outlier filtering, a dataset of 96 paired observations was compiled. Five-fold cross-validated models achieved R^2 values from 0.86 to 0.95, with chlorophyll-a ($R^2=0.95$) and phycocyanin ($R^2=0.94$) best predicted. SHAP (SHapley Additive exPlanations) analysis provided global and local feature attributions, validating that the physical principles of water reflectance were preserved—e.g., RedEdge bands dominated pigment predictions while Red-668 was most influential for turbidity and Secchi depth. These findings underscore the method's ability to capture the optical complexity of eutrophic systems and highlight its transferability across different temporal scales and aquatic environments, offering a robust and interpretable framework for water quality monitoring.

Resumo: A crescente degradação de reservatórios urbanos demanda métodos de monitoramento capazes de gerar dados precisos, de baixo custo e alta resolução. Este trabalho avaliou a aplicação de VANTs equipados com sensor multiespectral (MicaSense RedEdge Dual-P) e algoritmo Random Forest para estimar quatro parâmetros de qualidade da água — clorofila-a, ficocianina, turbidez e profundidade Secchi — no reservatório de Ibitité (MG). Foram realizadas seis campanhas mensais em 19 pontos, sincronizando coletas in situ e imagens aéreas. Após correção radiométrica, extração de reflectâncias e filtragem de *outliers*, construiu-se um banco de dados com 96 amostras. Modelos treinados com validação cruzada 5-fold apresentaram R^2 entre 0,86 e 0,95, com melhor desempenho para clorofila-a ($R^2=0,95$) e ficocianina ($R^2=0,94$). A técnica SHAP (*SHapley Additive exPlanations*) elucidou a importância global e local de cada banda, confirmando que o comportamento físico-teórico da reflectância foi respeitado—por exemplo, a dominância de bandas RedEdge para pigmentos e Red-668 para turbidez e secchi. Os resultados evidenciam a capacidade do método em capturar a complexidade óptica de ambientes eutrofizados, sugerindo ampla aplicabilidade a outros corpos d'água e períodos sazonais, com alto grau de interpretabilidade e confiabilidade.

Palavras-Chave – sensoriamento remoto multiespectral; qualidade da água em reservatórios; inteligência artificial explicável

1) Programa de Pós-graduação em Saneamento, Meio Ambiente e Rec. Hídricos/UFMG; caiocsmello@gmail.com

2) Programa de Pós-graduação em Saneamento, Meio Ambiente e Rec. Hídricos/UFMG; danielhcsalim@gmail.com

3) Programa de Pós-graduação em Saneamento, Meio Ambiente e Rec. Hídricos/UFMG; bernardoo.tadeu@gmail.com

4) Departamento de Geociências (DEGEO)/UFSJ; pereira@ufsj.edu.br

5) Departamento de Eng. Sanitária e Ambiental (DESA)/UFMG; camila@desa.ufmg.br

INTRODUÇÃO

A degradação ecológica de ambientes aquáticos, resultante de atividades humanas como escoamento agrícola, desmatamento e lançamento de esgoto doméstico e industrial, compromete a saúde e os serviços ecossistêmicos dos reservatórios urbanos (Lai *et al.*, 2024). Essa pressão, somada à variabilidade sazonal entre períodos secos e chuvosos, impacta diretamente os parâmetros de qualidade da água, como turbidez, clorofila-a, ficocianina e profundidade da zona fótica (Bieroza *et al.*, 2024).

A análise tradicional desses parâmetros, baseada em coletas e análises laboratoriais, demanda altos custos (Giardino *et al.*, 2014). Nesse cenário, os Veículos Aéreos Não Tripulados (VANTs) equipados com sensores remotos multiespectrais emergem como ferramentas promissoras para o monitoramento ambiental, oferecendo dados com alta resolução espacial, temporal e espectral (Salim *et al.*, 2024). Quando integrados a algoritmos de aprendizado de máquina, esses dados permitem modelagens mais precisas e adaptáveis à complexidade dos ambientes aquáticos (Assunção *et al.*, 2025).

O uso de algoritmos como *Random Forest* possibilita não apenas prever parâmetros com acurácia, mas também interpretar a relevância das variáveis por meio da análise de importância dos atributos em escala global e local (Molnar, 2025). Essa abordagem permite avaliação sobre a influência de bandas espectrais na modelagem de qualidade da água para diferentes parâmetros opticamente ativos (Lei *et al.*, 2024). Como destacado por Begliomini *et al.* (2023), tais métricas permitem analisar retrospectivamente modelos complexos, combinando desempenho preditivo com interpretação, o que é essencial para a validação científica dos resultados.

A aplicação de técnicas de inteligência artificial explicável (XAI), como SHAP (*SHapley Additive ExPlanations*), amplia a transparência dos modelos e sua coerência com processos biofísicos conhecidos (Molnar, 2025). Esse aspecto é particularmente relevante em ambientes heterogêneos e com diferentes estados tróficos, onde as relações espectrais podem variar significativamente.

Nesse contexto, este estudo se propõe a aplicar tecnologias na fronteira do conhecimento para estimar parâmetros de qualidade da água em reservatório urbano eutrofizado, utilizando sensoriamento remoto multiespectral de curta distância com VANT e algoritmo de aprendizagem de máquina *Random Forest*, avaliando os resultados do modelo com base em técnica de inteligência artificial explicável para proporcionar uma interpretação robusta dos efeitos das variáveis nas previsões do modelo.

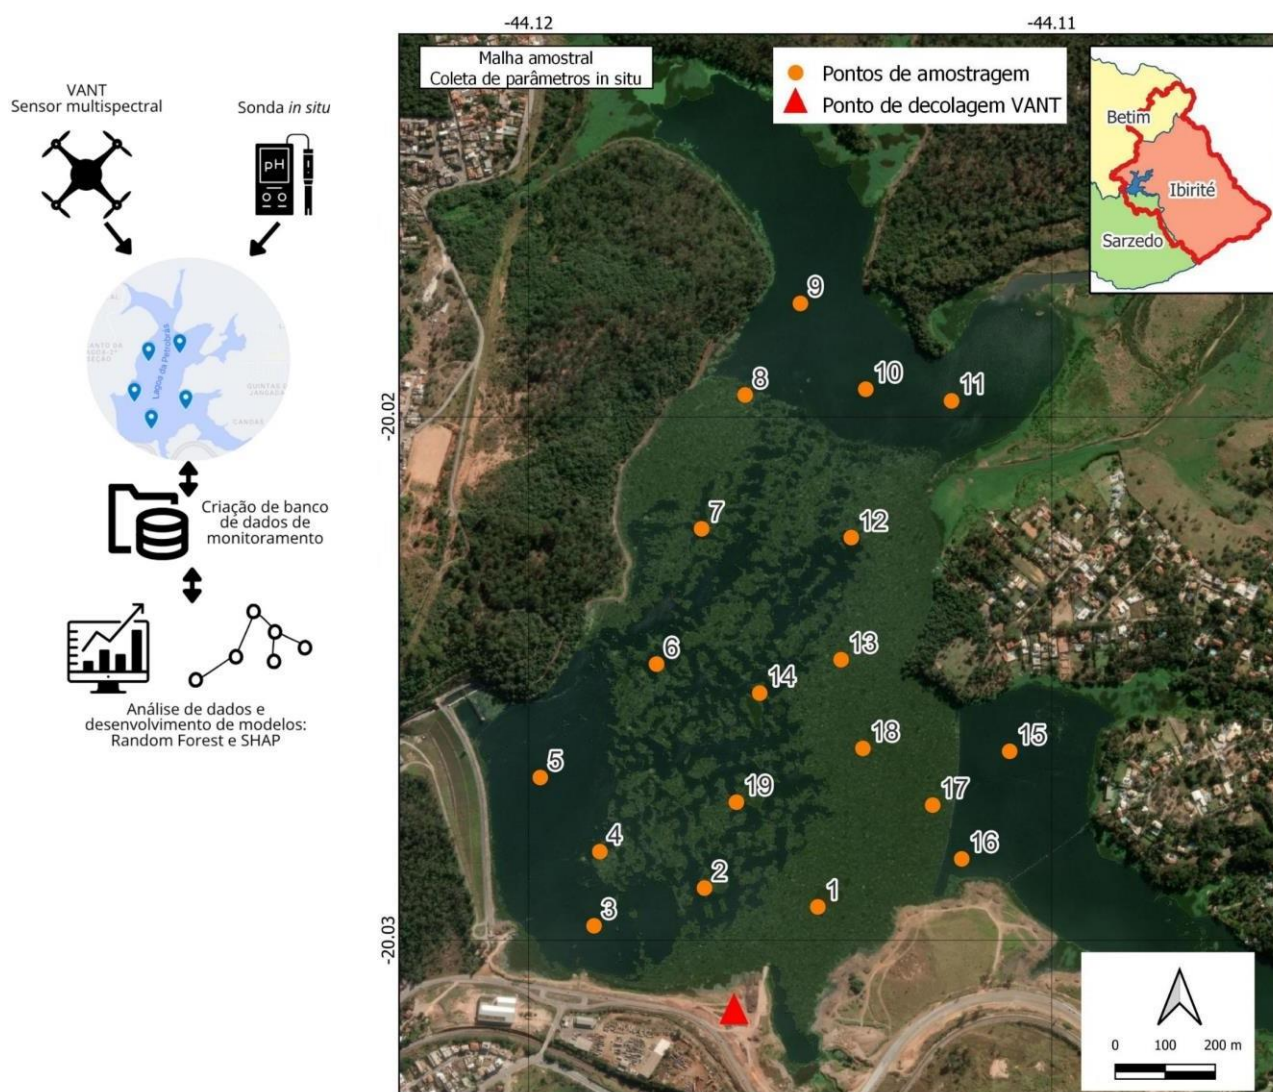
METODOLOGIA

O presente estudo foi desenvolvido no reservatório de Ibirité, localizado entre os municípios de Ibirité e Sarzedo, na Região Metropolitana de Belo Horizonte, Minas Gerais (Figura 1). Este reservatório, construído em 1968 para abastecer a Refinaria Gabriel Passos (REGAP - PETROBRÁS), pertence à bacia hidrográfica do rio Paraopeba e apresenta características de um reservatório monomítico quente, com estratificação térmica prolongada ao longo do ano (Souza *et al.*, 2023).

Classificado como um ambiente eutrofizado, o reservatório sofre pressões antrópicas decorrentes da intensa ocupação urbana e industrial da bacia de drenagem (Souza *et al.*, 2023). O lançamento de esgoto doméstico sem tratamento adequado e o uso do solo sem proteção de áreas ripárias contribuem significativamente para a entrada de nutrientes, matéria orgânica e poluentes,

favorecendo o crescimento de cianobactérias, a perda de qualidade da água e o avanço da eutrofização (Souza *et al.*, 2023).

Figura 1 – Fluxograma metodológico para coleta de dados e processamento, com detalhamento da malha amostral na área de estudo do reservatório de Ibitité.



O monitoramento da qualidade da água na área de estudo foi realizado com o uso integrado de sensoriamento remoto com VANT sincronizada com coletas *in situ*, conforme fluxograma da Figura 1. A amostragem foi realizada mensalmente em 19 pontos distribuídos estrategicamente ao longo do reservatório, durante um período de 06 meses, contemplando variações sazonais (agosto/2024 a fevereiro/2025), totalizando 06 campanhas. A determinação da malha amostral foi planejada de modo a cobrir os braços afluentes do reservatório a norte, nordeste e leste, bem como sua parte mais profunda na parcela central e próxima ao barramento. Também foi observada uma distância maior que 150m entre os pontos para não haver redundância de dados.

Nos pontos de amostragem, foram coletadas variáveis ópticas (turbidez, clorofila e ficocianina) com a sonda multiparâmetros ProDSS (YSI), além da profundidade da zona fótica através do disco de Secchi. Paralelamente, foram obtidas imagens de alta resolução com o VANT DJI Matrice 350,

equipado com o sensor multiespectral MicaSense RedEdge Dual, que captura 10 bandas espectrais distribuídas nas regiões do azul (444/475 nm), verde (531/560 nm), vermelho (650/668 nm), red edge (705/717 nm) e infravermelho próximo (740/842 nm) com uma resolução de 1,6 megapíxels por banda.

No processamento de imagens, as etapas incluem (Salim *et al.*, 2024): (i) correção radiométrica utilizando painéis de calibração (CRP Micasense) e metadados dos sensores; (ii) extração de métricas estatísticas de reflectância por banda em buffers ao redor dos pontos amostrais; (iii) remoção de outliers, filtrando valores extremos que possam afetar a modelagem. Os dados obtidos alimentam um banco de dados relacional estruturado com metadados completos (data, hora, local, condições climáticas, entre outros), permitindo análises comparativas e multitemporais. Após as filtragens e organização, o banco de dados final foi constituído por um total de 96 pares de dados.

Na etapa analítica, foram desenvolvidos modelos de regressão de aprendizado de máquina não-lineares, como Random Forest Regressor, com avaliação de desempenho por métricas como R^2 e RMSE. As etapas de treinamento e teste do modelo foram realizadas com validação cruzada (5-fold), de modo a evitar viés na construção da regressão, minimizando *overfitting* (Begliomini *et al.*, 2023).

Para interpretar os modelos *Random Forest*, foi aplicada a metodologia SHAP (SHapley Additive exPlanations), que permite avaliar a importância global de cada variável e também sua influência local, ponto a ponto, sobre as previsões dos modelos. Essa etapa fornece uma camada adicional de transparência ao modelo, facilitando a compreensão da relação entre características espectrais e parâmetros ambientais, além de contribuir para a seleção de variáveis mais representativas em diferentes contextos tróficos (Molnar, 2025).

RESULTADOS E DISCUSSÃO

Qualidade da água – monitoramento *in situ*


Os dados de qualidade da água obtidos no reservatório de Ibirité revelam características típicas de um ambiente lântico eutrofizado, refletindo os efeitos do aporte constante de nutrientes e matéria orgânica (Figura 2). A clorofila-a, que representa a biomassa fitoplanctônica, apresentou concentrações entre 10,9 $\mu\text{g/L}$ e 136,76 $\mu\text{g/L}$, com mediana de 59,68 $\mu\text{g/L}$ e desvio padrão de 32,94 $\mu\text{g/L}$. Esses valores elevados e com ampla variabilidade são compatíveis com ambientes altamente produtivos, indicando crescimento de algas estimulado por fontes difusas e pontuais de nutrientes.

Em relação à ficocianina, pigmento indicativo da presença de cianobactérias, os valores oscilaram entre 4,83 e 20,78 RFU, com mediana de 11,08 RFU e o desvio padrão 4,75 RFU, sugerindo uma presença persistente e relevante desses microrganismos ao longo do tempo. Essa tendência é compatível com os processos de eutrofização e estratificação térmica, que favorecem a proliferação de cianobactérias em ambientes ricos em nutrientes e com baixa renovação hídrica.

A turbidez, por sua vez, variou entre 0,16 e 22,11 NTU, com mediana de 10,12 NTU. O desvio padrão de 4,53 NTU indica flutuações moderadas, frequentemente associadas ao transporte de material particulado oriundo da bacia hidrográfica, especialmente durante eventos de chuva. A presença de matéria orgânica e de sedimentos em suspensão, combinada à intensa atividade biológica, contribui para a opacidade da coluna d'água observada.

A transparência da água, medida pelo disco de secchi, apresentou variação de 30 cm a 110 cm, com mediana de 55,57 cm e desvio padrão de 16,92 cm. A baixa profundidade de visibilidade está diretamente relacionada à elevada concentração de algas e também atrelada ao material em suspensão, comprometendo a penetração da luz.

Figura 2 – Boxplots da variação dos parâmetros opticamente ativos de qualidade da água monitorados durante as campanhas de campo: clorofila, ficocianina, profundidade do disco de secchi e turbidez.




Assinaturas espectrais – imageamento multiespectral

A análise das assinaturas espectrais médias obtidas pelo sensor MicaSense RedEdge Dual-P no Reservatório de Ibitiré/MG (Figura 3) revelou padrões característicos de ambientes lênticos eutrofizados. Os espectros médios indicaram picos de refletância nas bandas do verde (531 nm) e do RedEdge (705 nm), enquanto vales foram observados nas bandas do azul (444 nm) e do vermelho (650 nm). Esse comportamento é consistente com a presença de elevados níveis de clorofila-a, que absorve fortemente nos comprimentos de onda do azul e vermelho e reflete no verde e RedEdge. A queda acentuada no vermelho (Red-650 e Red-668) está alinhada ao pico de absorção da clorofila-a em torno de 665 nm (Burket *et al.*, 2023).

A variabilidade das assinaturas espectrais no MicaSense, expressa pelos intervalos interquartis e percentis 10–90%, evidenciou flutuações significativas nas bandas Green-531 e RedEdge-705, associadas à variabilidade na concentração de fitoplâncton e material particulado. A faixa do NIR (842 nm) também apresentou grande variabilidade, possivelmente relacionada a ruídos nas imagens, sombras ou diferenças de turbidez.

Figura 3 – Variação da resposta espectral dos pontos amostrados no reservatório de Ibirité ao longo das 06 campanhas realizadas.

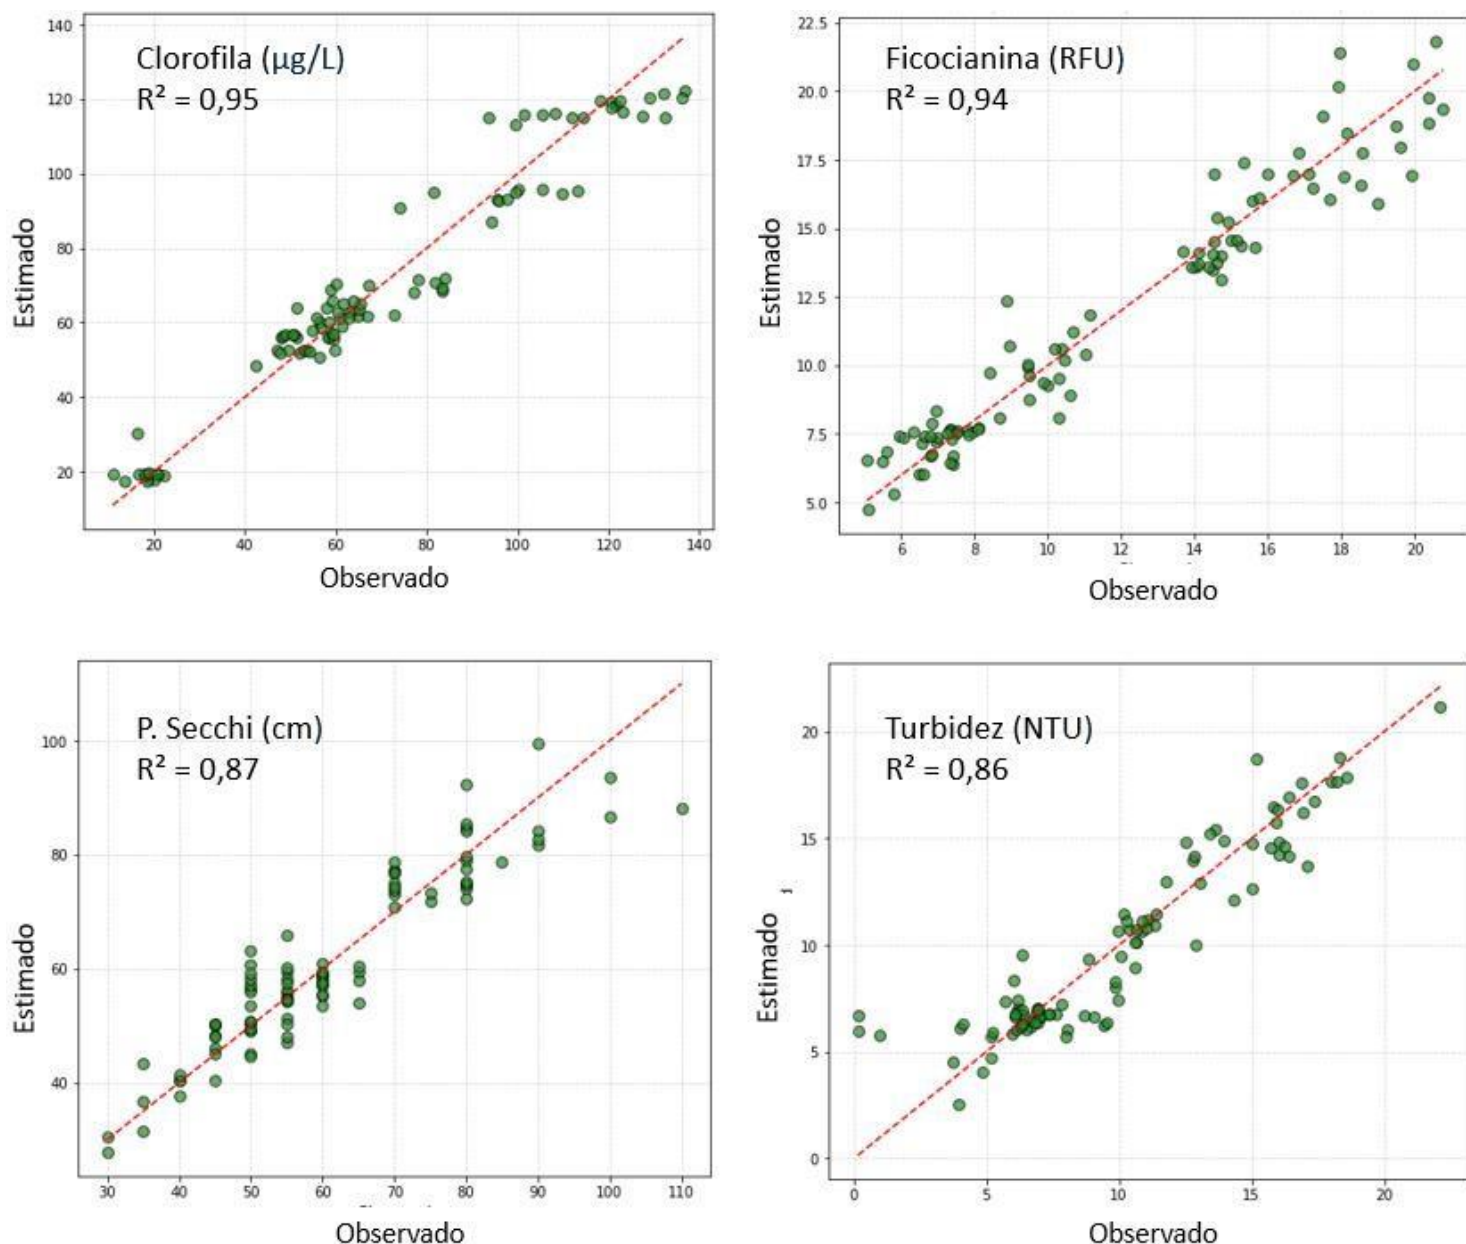


Desempenho dos modelos de regressão

Em relação ao desempenho dos modelos de regressão, os resultados apresentados nos gráficos de dispersão (Figura 4) evidenciam a performance do modelo Random Forest na estimativa de parâmetros de qualidade da água a partir dos dados espectrais do sensor MicaSense RedEdge Dual-P no Reservatório de Ibirité/MG. De modo geral, os modelos apresentaram bons desempenhos de predição, com coeficientes de determinação (R^2) elevados para todas as variáveis analisadas:

- **Clorofila-a ($R^2 = 0,95$):** O modelo apresentou excelente desempenho, refletindo a forte relação entre a presença de clorofila e as bandas do espectro eletromagnético, especialmente o RedEdge-717 nm, que foi identificado como a principal variável explicativa. A alta refletância nesta faixa está associada à transição da absorção para a reflexão na estrutura celular do fitoplâncton, o que justifica a elevada acurácia.
- **Ficocianina ($R^2 = 0,94$):** Também estimada com alta precisão, sendo a banda azul (Blue-475 nm) a mais correlacionada. A absorção da luz azul por pigmentos de cianobactérias como a ficocianina favorece a discriminação por bandas do espectro visível, especialmente em ambientes eutrofizados.
- **Secchi ($R^2 = 0,87$):** A estimativa da profundidade de transparência foi satisfatória, embora com menor precisão relativa. A explicação plausível está no fato de que a transparência da água é afetada por múltiplos fatores, como concentração de clorofila-a, partículas inorgânicas e matéria orgânica dissolvida. A banda Red-668 nm foi a mais sensível, refletindo o efeito da absorção de pigmentos e detritos suspensos na redução da transparência.
- **Turbidez ($R^2 = 0,86$):** Embora com bom desempenho, o modelo encontrou maior dificuldade na predição da turbidez. Isso é esperado, pois a turbidez resulta da soma de fatores como sedimentos em suspensão, matéria orgânica e algas, os quais possuem assinaturas espectrais sobrepostas. Novamente, a banda Red-668 nm foi a mais significativa, indicando o papel central dos pigmentos fotossintéticos e partículas em suspensão na resposta espectral.

Figura 4 – Resultados das modelagens *Random Forest* para clorofila, ficocianina, profundidade do disco de secchi e turbidez com visualização da regressão (dados observados vs. dados estimados).



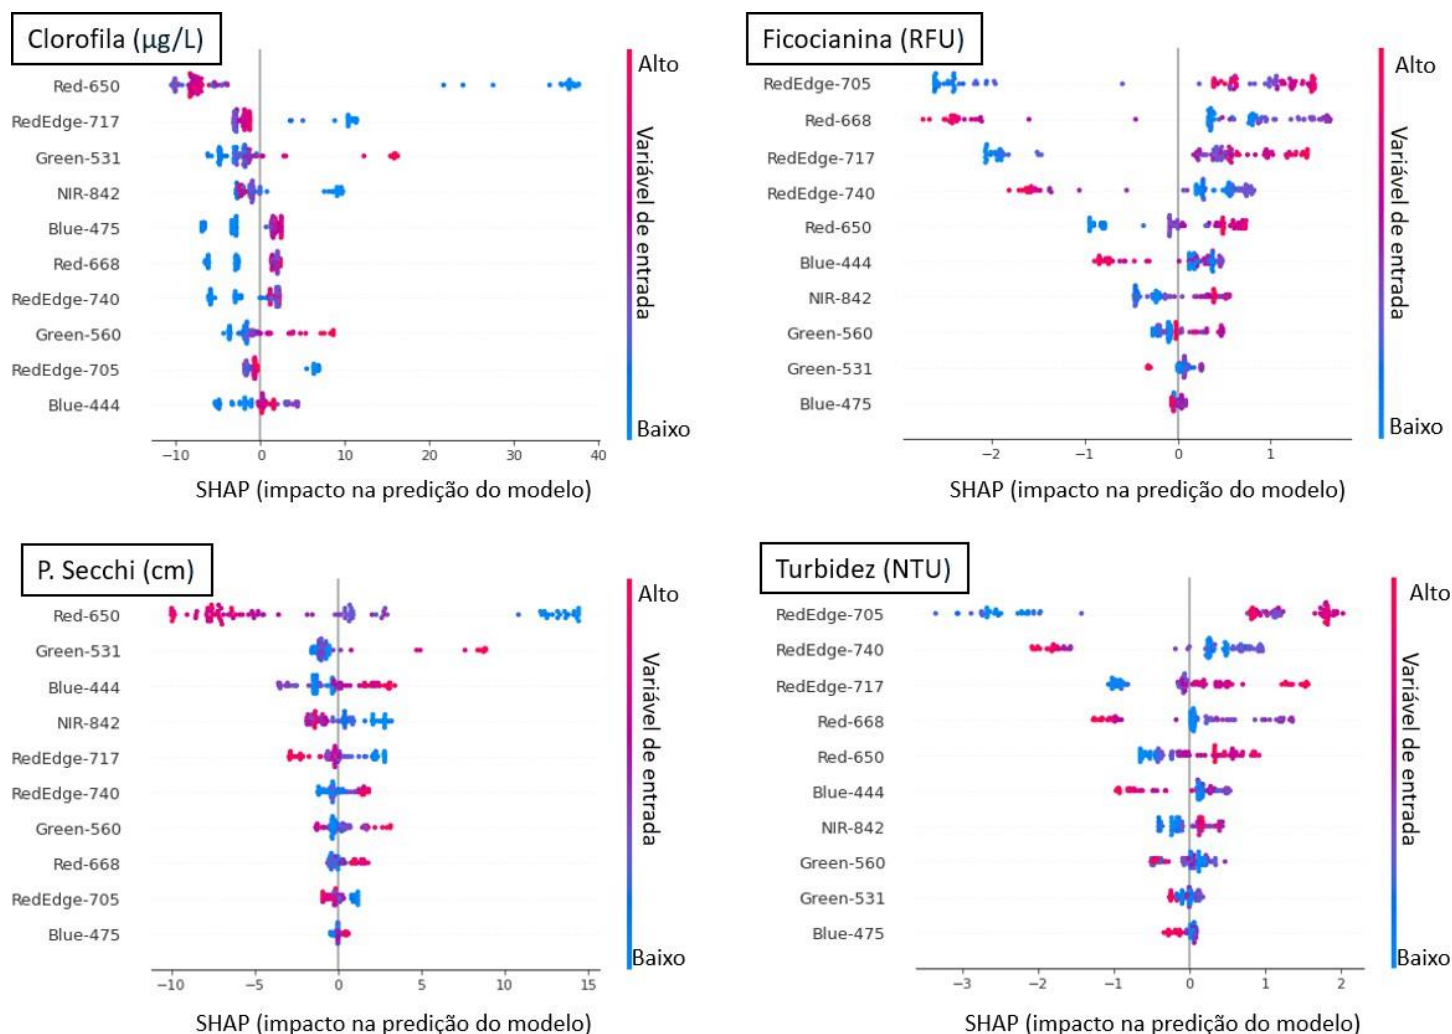
Em síntese, os modelos *Random Forest* mostraram robustez e capacidade de generalização, especialmente para pigmentos fotossintéticos como clorofila-a e ficocianina. Contudo, parâmetros como turbidez e Secchi, que sofrem influência direta da clorofila e de outros fatores ópticos, apresentam desafios adicionais, sobretudo em águas opticamente complexas como a do reservatório de Ibitité. Esses resultados evidenciam a importância de usar modelos não-lineares, como o *Random Forest*, capazes de lidar com múltiplas variáveis correlacionadas e interações não triviais entre os fatores ambientais.

Avaliação explicativa do modelo de aprendizagem de máquina

A análise dos gráficos SHAP aplicados aos modelos de *Random Forest* com dados espectrais do sensor evidencia o grau de influência de cada banda na predição dos parâmetros de qualidade da

água (Figura 5), com padrão de coloração dos pontos com valores altos da variável espectral (em vermelho) associados a impactos positivos e valores baixos (em azul) com impacto negativo da respectiva banda no resultado de predição do modelo.

Figura 5 – Resultados da avaliação de impacto global e local via SHAP para clorofila, ficocianina, profundidade do disco de secchi e turbidez.



Para a clorofila, observa-se uma clara dominância das bandas Red-650 e RedEdge-717, que apresentaram os maiores valores absolutos de impacto global no modelo. Isso é consistente com o comportamento óptico da clorofila-a, que absorve fortemente na faixa do vermelho (~665 nm) e possui uma inflexão característica na região do RedEdge. A contribuição da banda Green-531 também é significativa, reforçando a resposta na região visível onde a clorofila interage com a luz incidente. O padrão de coloração dos pontos confirma a coerência física do modelo, com valores altos de Red-650 (em vermelho) impactando na redução da predição, e o contrário ocorrendo para Green-531. A distribuição dos pontos SHAP é bem definida e separável, indicando boa distinção espectral (ou separabilidade espectral) entre as variáveis utilizadas na predição da clorofila-a.

Para a ficocianina, destaque para as bandas RedEdge-705, Red-668 e RedEdge-717, que apresentaram maior contribuição na predição da variável. Essa predominância na transição entre o

vermelho e o infravermelho próximo está associada à resposta óptica das cianobactérias, que expressam pigmentos com características espectrais similares à clorofila, como a própria ficocianina. No entanto, há maior sobreposição funcional entre as bandas relevantes, principalmente em RedEdge-705 e Red-668, o que reduz a capacidade do modelo em distinguir com precisão entre fontes diferentes de variação espectral. Esse fenômeno, cientificamente reconhecido como redução da capacidade de discriminação espectral, dificulta a segmentação entre os efeitos específicos de pigmentos distintos em ambientes opticamente complexos. No entanto, esse efeito é menos observado em RedEdge-717, RedEdge 740 e Red-650, o que pode ter sido fundamental para o bom desempenho do modelo na estimativa de ficocianina.

No caso da profundidade de transparência (Secchi), a banda Red-650 apresentou o maior impacto no modelo, sendo que as demais bandas apresentaram impactos de ordem similar. Isso reflete a interação conjunta entre absorção por pigmentos, espalhamento por partículas e matéria orgânica em suspensão, que influenciam a visibilidade vertical da coluna d'água. O padrão de coloração para vermelho demonstra que valores altos de reflectância impactam na redução da transparência e vice-versa. Por outro lado, observa-se que a reflectância em verde e azul possui comportamento contrário no que tange ao padrão de cores. Estes resultados se mostram condizentes com a teoria ótica esperada.

Por fim, para turbidez, as bandas do RedEdge (705, 740 e 717) lideram a contribuição nos modelos, com Red (668 e 650) e Blue-444 também desempenhando papéis relevantes. A turbidez, por ser um parâmetro influenciado por múltiplos constituintes opticamente ativos — como partículas inorgânicas, fitoplâncton e matéria orgânica dissolvida —, apresenta naturalmente maior ambiguidade espectral, ou seja, uma dificuldade em distinguir as contribuições específicas de cada componente na resposta espectral. No entanto, a dispersão dos pontos SHAP na região do RedEdge e Red demonstram boa segmentação a influência da reflectância nessas bandas para estimativa da turbidez, com destaque para o comportamento apresentado pelo Red-668, onde maiores valores de reflectância influenciaram positivamente na estimativa da turbidez, mostrando a consistência física do modelo de regressão.

Por fim, os achados demonstram que a clorofila-a apresentou a maior capacidade preditiva, com clara separabilidade espectral entre as bandas, enquanto ficocianina, turbidez e profundidade Secchi exibiram níveis crescentes de ambiguidade óptica, demandando modelos mais sofisticados para capturar a complexidade inerente a ecossistemas eutrofizados, como o reservatório de Ibitaré. A aplicação da análise SHAP revelou, de forma detalhada, o impacto individual de cada banda na predição, corroborando que o comportamento físico-teórico da reflectância — conforme previsto pela óptica de corpos d'água — foi efetivamente respeitado pelo modelo. Esse alinhamento entre teoria e prática reforça a robustez das previsões, atestando que o “desempenho de caixa-preta” se deve a fundamentos físicos pertinentes, e não a artifícios estatísticos ou sobreajuste. Dessa forma, nossa abordagem demonstra elevada confiabilidade e sugere potencial de generalização a outras séries temporais e ambientes, sem receio de resultados espúrios.

CONSIDERAÇÕES FINAIS

Este estudo demonstrou a eficácia do sensoriamento remoto multiespectral por VANT integrado a algoritmos de Random Forest na estimativa de parâmetros de qualidade da água em reservatório urbano eutrofizado. A clorofila-a revelou-se o parâmetro mais bem previsto, graças à forte separabilidade espectral das bandas associadas à absorção e reflexão desse pigmento. Ficocianina, turbidez e profundidade Secchi apresentaram maior ambiguidade óptica, exigindo modelagens mais complexas para lidar com interações espectrais sobrepostas em águas ricas em nutrientes. A análise SHAP confirmou que o modelo respeita as leis físicas da reflectância — por

exemplo, picos de importância em bandas do RedEdge para clorofila e Red-668 para turbidez e Secchi — reforçando a confiabilidade dos resultados. A robustez e coerência dos achados sugerem que esse framework pode ser estendido a outras séries temporais e corpos d'água, fornecendo uma ferramenta escalável e interpretável para monitoramento ambiental.

AGRADECIMENTOS

Os autores agradecem à Petrobras/ANP pelo financiamento do projeto de pesquisa e desenvolvimento AQUASmart, no âmbito do qual esta pesquisa foi realizada. Agradecem também à equipe técnica e aos colegas envolvidos nas coletas e no processamento dos dados, bem como à UFMG pela disponibilização de equipamentos e suporte logístico para o desenvolvimento do trabalho. Ainda, agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio contínuo.

REFERÊNCIAS

- ASSUNÇÃO, A.; SILVA, T.F.G.; DE CARVALHO, L.A.S.; VINÇON-LEITE, B. (2025). “Assessing water quality restoration measures in Lake Pampulha (Brazil) through remote sensing imagery”. *Environmental Science and Pollution Research*, —. <https://doi.org/10.1007/s11356-025-35914-6>
- Begliomini, F.N.; Barbosa, C.C.F.; Martins, V.S.; Novo, E.M.L.M.; Paulino, R.S.; Maciel, D.A.; Lima, T.M.A.; O'Shea, R.E.; Pahlevan, N.; Lamparelli, M.C. (2023). “Machine learning for cyanobacteria mapping on tropical urban reservoirs using PRISMA hyperspectral data”. *ISPRS Journal of Photogrammetry and Remote Sensing*, 205, pp. 160–174. <https://doi.org/10.1016/j.isprsjprs.2023.09.019>
- Burket, M.O.; OLMANSON, L.G.; BREZONIK, P.L. (2023). “Comparison of two water color algorithms: implications for the remote sensing of water bodies with moderate to high CDOM or chlorophyll levels”. *Sensors*, 23 (3), p. 1071. <https://doi.org/10.3390/s23031071>
- GIARDINO, C.; BRESCIANI, M.; STROPPIANA, D.; OGGIONI, A.; MORABITO, G. (2014). “Optical remote sensing of lakes: an overview on Lake Maggiore”. *Journal of Limnology*, 73 (s1), pp. 201–214. <https://doi.org/10.4081/jlimnol.2014.817>
- LAI, Y.; ZHANG, J.; LI, W.; SONG, Y. (2024). “Water quality monitoring of large reservoirs in China based on water color change from 1999 to 2021”. *Journal of Hydrology*, 633, p. 130988. <https://doi.org/10.1016/j.jhydrol.2024.130988>
- LEI, X.; JIANG, J.; DENG, Z.; WU, D.; WANG, F.; LAI, C.; WANG, Z.; CHEN, X. (2024). “An ensemble machine learning model to estimate urban water quality parameters using unmanned aerial vehicle multispectral imagery”. *Remote Sensing*, 16 (12), p. 2246. <https://doi.org/10.3390/rs16122246>
- MOLNAR, C. (2025). “Interpretable Machine Learning: a guide for making black box models explainable” (3rd ed.). Disponível em: <http://christophm.github.io/interpretable-mlbook/>
- SALIM, D.H.C.; ANDRADE, G.R.; ASSUNÇÃO, A.F.; COSME, P.H.M.; PEREIRA, G.; AMORIM, C.C. (2024). “Assessing the impact of environmental conditions on reflectance values in inland waters using multispectral UAS imagery”. *Limnology and Freshwater Biology Reviews*, 24 (2), pp. 466–490. <https://doi.org/10.3390/limnolrev24040027>
- SOUZA, P.C.; PUJONI, D.G.F.; BARROS, C.F.A. (2023). “O ribeirão Ibitaré como fonte de cianobactérias para a Lagoa da Petrobrás, MG: uma análise preliminar”. In: BASQUEROTE, A.T. (Ed.), *Biodiversidade, meio ambiente e desenvolvimento sustentável*. Editora Conhecimento Livre, pp. 1–28. <https://doi.org/10.37423/230307408>
- ZIEN, A.; RÄTSCH, G.; MIKA, S.; SCHÖLKOPF, B. (2009). “Feature importance ranking measure (FIRM): an efficient approach to retrieve relevant features in nonlinear models”. In: *Advances in Machine Learning*. Springer, pp. 694–712. https://doi.org/10.1007/978-3-642-04174-7_45